

IFG Progress Weekly Digest

Real-Time Tracking Indonesia's GDP: Machine Learning

November 29, 2022 - Issue 9, 2022


Reza Yamora Siregar, Head of IFG-Progress, reza.jamora@ifg.id

Rizky Rizaldi Ronaldo, Research Associate, rizky.rizaldi@ifg.id

- *Extreme volatility, unexpected shocks, dan ketidakstabilan kondisi ekonomi membuat real-time tracking kondisi ekonomi Indonesia menjadi sangat krusial. Menunggu rilis data ± 35 hari setelah kuartal selesai atau ± 90 hari setelah bulan pertama berakhir tidak lagi memadai;*
- *Real-time tracking Indonesia's GDP dengan menggunakan model machine learning dan ekonometrik terbukti menghasilkan angka yang cukup akurat. Angka tersebut dapat berperan sebagai Early Warning System (EWS) dalam mengambil keputusan strategis, baik untuk pemerintah maupun stakeholder lainnya.*

Real-time monitoring & prediksi akurat terhadap indikator ekonomi merupakan hal yang sangat penting bagi seluruh stakeholder, baik dari pihak pemerintah hingga swasta. Dengan Informasi arah perekonomian yang presisi, pemerintah dan swasta dapat memformulasikan kebijakan yang tepat dan relevan, terlebih ketika kondisi perekonomian dikelilingi ketidakpastian (Covid-19, konflik geopolitik, dan lain-lain). Akan tetapi, dengan kondisi indikator utama perekonomian (Gross Domestic Product – GDP) yang bersifat kuartalan dan *lagging*, banyak pihak tidak dapat hanya bergantung pada indikator GDP. Di Indonesia sendiri, Badan Pusat Statistik (BPS) baru akan mempublikasikan indikator GDP ± 35 hari setelah kuartal selesai. Artinya, performa perekonomian pada bulan ke-1, 2, & 3 baru akan terlihat 35 hari setelah bulan ke-3 berakhir. Hal ini mengindikasikan bahwa semua pihak baru dapat mengevaluasi kondisi yang terjadi di bulan ke-1 pada lebih dari ± 90 hari setelah bulan tersebut berakhir.

Exhibit 1. Real-Time Tracking Indonesia's GDP: Machine Learning Research Framework




Sumber: IFGP Research.

Dengan adanya model prediksi (*Forecasting & Nowcasting*) yang akurat, minimal revisi, dan memiliki frekuensi tinggi, seluruh stakeholder perekonomian dapat menyiapkan kebijakan strategis di waktu yang tepat (Exhibit 1).

Pada *Weekly Digest #9*, kami mencoba membangun model *Forecasting & Nowcasting* yang akurat untuk membantu berbagai *stakeholder* dan berperan sebagai suatu *Early Warning System (EWS)*. Dalam membangun model ini, kami menggunakan model *machine learning* dan ekonometrik untuk memproduksi model yang robust. Secara keseluruhan, terdapat 3 tahapan proses dalam model ini, seperti yang tertera pada Exhibit 2.

Exhibit 2. Tahapan Pembuatan Model IFG Progress




Sumber: IFGP Research.

Tahap pertama untuk membangun model ini adalah menentukan kumpulan seri atau variabel yang memenuhi tiga syarat, yaitu: 1) *Relevan*, 2) *High-frequency*, dan 3) *Timely & low-revision*. Dalam menentukan variabel-variabel yang memenuhi tiga syarat tersebut, kami mengumpulkan sebanyak 235 variabel yang terdiri dari 99 variabel dari sektor riil, 68 variabel dari sektor moneter, 30 variabel dari sektor eksternal serta 38 variabel dari sektor lainnya (Exhibit 3).

Selanjutnya, pada tahap kedua, kami menyortir dan menganalisis seluruh variabel untuk memilih kumpulan variabel yang akan kami gunakan dalam model. Di tahapan ini, kami menggunakan dua metode khusus, selain deskriptif grafik, dalam menentukan periode *turning points*, kontraksi & ekspansi, yaitu 1) Bry-Boschan¹, dan 2) Granger-Causality². Dari tahapan ini, kami dapat mengelompokkan variabel-variabel tersebut menjadi tiga kategori, yaitu 1) *leading*, 2) *coincident*, dan 3) *lagging*. Kami hanya menggunakan variabel yang bersifat *leading* sebagai input dari model kami.³

Di tahap terakhir, kami mulai menjalankan model yang kami gunakan berdasarkan input yang diperoleh sebelumnya. Framework yang digunakan terdiri dari tiga langkah. Langkah pertama dan kedua bersifat *looping*, ketika variabel yang kami gunakan dirilis, model secara otomatis dijalankan dan menghasilkan angka estimasi terbaru. Iterasi dari langkah 1 and 2 terus dilakukan sampai data aktual dari indikator target (seperti GDP) telah dirilis. Di langkah ketiga, kami menginput data yang tersedia setelah variabel target dirilis sebagai bahan *backcast*, dan estimasi periode selanjutnya (Exhibit 4).

Exhibit 3. Jumlah Variabel Berdasarkan Kategori




Sumber: Berbagai sumber, IFGP Research. Catatan: Klasifikasi Others merupakan klasifikasi yang tergolong seperti survey dan alternatif data lainnya. Klasifikasi Additional merupakan data spesifik, khusus, dan tidak terbuka untuk publik.

¹ Bry, G., & Boschan, C. (1971). Programmed selection of cyclical turning points. In *Cyclical analysis of time series: Selected procedures and computer programs* (pp. 7-63). NBER, dan Harding, D., & Pagan, A. (2002). Dissecting the cycle: a methodological investigation. *Journal of monetary economics*, 49(2), 365-381.

² Granger, C. W. J. 1969. Investigating causal relations by econometric models and cross-spectral methods. *Econometrica* 37: 424-438. dan Dumitrescu, E.-I., and C. Hurlin. 2012. Testing for Granger non-causality in heterogeneous panels. *Economic Modelling* 29: 1450-1460.

³ Daftar variabel yang digunakan tercantum pada *Appendix*.

Exhibit 4. Tiga Tahapan Dalam Mengestimasi Model IFGP


Sumber: Berbagai sumber, IFGP Research.

Metode yang kami gunakan merupakan campuran antara model *machine learning* dan ekonometrik yang terdiri dari 1) *Long-Short Term Memory (LSTM)*, 2) *Autoregressive Moving Average (ARMA)*, 3) *Decision tree (DT)*, 4) *Multilayer Perceptron (MLP)*, 5) *OLS Ridge*, 6) *Random Forest (RF)*, dan 7) *Gradient Boost (XGBoost)*⁴. Metode-metode ini sudah banyak digunakan baik oleh analis pasar, akademis, dan juga institusi global seperti the *U.S. Federal Reserve*.

Testing Period: Finding The Right Models

Untuk memilih model terbaik, kami melakukan tiga *event study* yang terdiri dari 1) *United States (US) Tightening Cycle* pada periode September 2017 – Juni 2018, 2) *‘Trade War’* pada Maret 2018 – Desember 2019, dan 3) *Covid-19* pada periode Maret 2020 – sekarang. Tiga periode tersebut dipilih untuk menguji bagaimana performa model yang kami gunakan ketika dalam periode ketidakstabilan. Periode yang dipilih utamanya merupakan fluktuasi yang bersumber dari luar Indonesia. Hal ini disebabkan oleh fakta bahwa belum adanya fluktuasi domestik yang dapat mengganggu performa ekonomi Indonesia⁵ (pertumbuhan ekonomi Indonesia cukup stabil di angka $\pm 5.45\%$ - rata-rata pertumbuhan Maret 2009 – Desember 2019).

Untuk periode *US Tightening Cycle*, berdasarkan analisis *Root Mean Square Error (RMSE)*⁶, seluruh model yang digunakan menunjukkan nilai RMSE yang cukup baik dengan seluruhnya berada di bawah <1 (kecuali model MLP pada periode +2). Model LSTM dan ARMA merupakan dua model yang menunjukkan performa terbaik. Masing-masing LSTM dan ARMA menghasilkan nilai RMSE yang berkisar masing-masing di antara 0.28 – 0.36 dan 0.08 – 0.11. Angka ini menunjukkan bahwa LSTM dan ARMA dapat mengestimasi nilai GDP dengan *error* dan revisi yang sangat minim. Selain itu, model RF juga menunjukkan nilai RMSE yang cukup baik dengan kisaran di antara 0.20 – 0.26. Model dengan RMSE terbesar adalah model XGBoost dengan kisaran di antara 0.45 – 0.89 (Exhibit 5).

Selanjutnya, untuk periode *‘Trade War’*, secara keseluruhan nilai RMSE juga menunjukkan nilai yang cukup baik dan

Exhibit 5. Testing Period 1: Siklus Pengetatan The Fed

Periode	US Tightening Cycle						
	Methodologies						
	LSTM	ARMA	DT	MLP	OLS Ridge	RF	XGBoost
-2	0.28	0.08	0.53	0.52	0.20	0.34	1.03
-1	0.35	0.11	0.54	0.46	0.67	0.42	0.83
0	0.36	-	0.54	0.62	0.81	0.50	0.90
+1	0.32	-	0.50	0.73	0.78	0.45	0.65
+2	0.34	-	0.39	1.13	0.41	0.56	0.39

Sumber: IFGP Research. Catatan: Angka dengan bold dan bayang abu merupakan dua RMSE terkecil pada periode pengujian. Periode -2 dan -1 merupakan forecast, periode 0 merupakan nowcast, dan periode +1 dan +2 adalah backcast (revisi). Training sampel Januari 2002 – Juni 2017. Testing sampel September 2017 – Juni 2018.

Exhibit 6. Testing Period 2: ‘Trade War’

Periode	Trade War						
	Methodologies						
	LSTM	ARMA	DT	MLP	OLS Ridge	RF	XGBoost
-2	0.27	0.15	0.42	0.64	0.29	0.20	0.89
-1	0.29	0.12	0.41	0.43	0.67	0.22	0.62
0	0.27	-	0.48	0.29	0.77	0.26	0.54
+1	0.21	-	0.46	0.21	0.75	0.22	0.47
+2	0.21	-	0.41	0.19	0.79	0.23	0.45

Sumber: IFGP Research. Catatan: Angka dengan bold dan bayang abu merupakan dua RMSE terkecil pada periode pengujian. Periode -2 dan -1 merupakan forecast, periode 0 merupakan nowcast, dan periode +1 dan +2 adalah backcast (revisi). Training sampel Januari 2002 – Desember 2017. Testing sampel Maret 2018 – Desember 2019.

⁴ Appendix

⁵ Sebatas pemahaman penulis sebelum Covid-19

⁶ RMSE memperhitungkan selisih antara nilai estimasi dan aktual. Semakin kecil nilai RMSE, semakin baik model dalam mengestimasi variabel target.

seluruhnya berada di bawah <1. Pada *testing period 2* ini, LSTM, ARMA, dan RF merupakan tiga model dengan nilai RMSE terbaik, sedangkan Model OLS Ridge dan XGBoost merupakan dua model dengan nilai RMSE terbesar (Exhibit 6).

Exhibit 7. Testing Period 3: Corona Virus 2019 (Covid-19) – Pseudo Out Of Sample (POOS)

Covid-19									
Date	Actual	Prediction							Delta (Actual - Prediction)
		LSTM	ARMA	DT	MLP	OLS Ridge	RF	XGBoost	
Mar-20	2.97	4.09	3.45	4.97	5.23	6.53	4.99	4.99	-1.12
Jun-20	-5.32	-2.29	-4.78	4.85	7.69	-6.71	4.21	4.28	-0.48
Sep-20	-3.49	-3.08	-1.92	1.78	-1.85	-2.89	1.19	-4.78	-0.54
Dec-20	-2.17	-2.42	-1.39	-0.68	-4.33	2.83	0.55	-1.99	-0.41
Mar-21	-0.70	-0.82	-0.01	-2.43	-0.18	-1.07	0.51	1.12	-0.78
Jun-21	7.07	4.45	6.55	1.39	27.58	24.99	3.88	3.09	-0.12
Sep-21	3.51	4.23	3.38	7.48	22.98	11.70	5.90	6.41	0.26
Dec-21	5.02	5.44	5.59	7.31	7.89	12.12	5.91	6.28	-0.69
Mar-22	5.01	5.31	3.84	5.40	4.51	2.10	5.37	5.85	1.73
Jun-22	5.44	5.44	6.55	5.95	4.77	-11.24	5.05	5.49	-0.52
Sep-22	5.72	5.61	6.89	5.83	9.26	-26.67	5.44	5.34	-0.26
Dec'22E*		4.52	5.88	5.93	6.92	15.11	5.37	4.74	-0.42
FY2022E*		5.14	5.82	5.56	6.68	-0.32	5.32	5.13	-0.30

Sumber: IFGP Research. Catatan: Untuk FY2022, pertumbuhan setiap metode pada Mar-22 & Jun-22 menggunakan actual growth dan pada Sep-22 & Dec-22 menggunakan predicted growth. Prediksi sementara menggunakan data terupdate hingga 1 November 2022. Angka dengan bold dan bayang abu merupakan dua RMSE terkecil pada periode pengujian. Periode -2 dan -1 merupakan forecast, periode 0 merupakan nowcast, dan periode +1 dan +2 adalah backcast (revisi)


Pada *Testing Period 3: Corona Virus 2019 (Covid-19)*, kami menggunakan metode *Pseudo-Out-Of-Sample (POOS)* untuk mengestimasi GDP setiap kuartal sejak Maret 2020. Dari hasil POOS pada Exhibit 7, model LSTM dan ARMA merupakan dua model yang menghasilkan nilai delta terkecil (aktual – prediksi). Rata-rata delta semenjak Maret 2020 – September 2022 untuk LSTM dan ARMA masing-masing sebesar -0.26 dan -0.46. Sedangkan kelima model lainnya, yaitu DT, MLP, OLS Ridge, RF, dan XGBoost masing-masing memiliki delta sebesar -1.71, -5.50, 1.03, -1.81, -1.18 (Exhibit 7).

What's Ahead?

Dengan menggunakan dua model terbaik dalam pengujian di atas, yaitu 1) LSTM, dan 2) ARMA, kami melakukan estimasi pertumbuhan *year-on-year* GDP untuk tahun 2023. Dengan kondisi saat ini dan data yang telah dirilis, *ceteris paribus*, model LSTM dan ARMA menghasilkan rentang pertumbuhan *Full Year (FY) 2023* sebesar 4.6% - 4.8%, di bawah angka 5.14% untuk FY 2022. (Exhibit 8)

In summary, dengan berbagai fluktuasi dan ketidakpastian, baik yang bersumber dari *geopolitical conflict*, *Commodity Price Crises*, *Tightening*, dan lain-lain, *real-time tracking* menjadi sangat penting dan krusial. Dengan menggunakan bantuan model *machine learning* dan ekonometrik, kami membuat model yang dapat membantu melacak *growth path* dengan tingkat akurasi yang tinggi dan *high-frequency*. Model LSTM dan ARMA dapat menjadi dua model acuan dalam melacak GDP secara *real-time* dengan tingkat *error (actual – prediction)* yang sangat rendah. Kedua model ini dapat menjadi suatu '*Early Warning System (EWS)*' dan landasan bagi berbagai pihak, seperti pemerintah, *market player*, dan lain-lain dalam mengambil keputusan strategis. Kedua model ini kedepannya akan secara berlanjut diperbarui dan dicantumkan di website ifgprogress.id


Exhibit 8. Hasil Estimasi Model LSTM & ARMA Untuk Pertumbuhan GDP (%Year-on-Year) Full Year 2023



Sumber: IFGP Research. Catatan: Angka prediksi bersifat sementara hingga seluruh data pada 2022 telah dirilis. Prediksi sementara menggunakan data terupdate hingga 1 November 2022

Appendix

Exhibit 9. Tujuh Model Yang Digunakan Sebagai Acuan Estimasi



Sumber: Berbagai sumber, IFGP Research.

Exhibit 10. References

- Ahmadi, M. et al. (2019) "Presentation of a new hybrid approach for forecasting economic growth using artificial intelligence approaches," *Neural Computing and Applications*, 31(12), pp. 8661–8680. Available at: <https://doi.org/10.1007/s00521-019-04417-0>.
- Bolhuis, M. and Rayner, B. (2020) "Deus Ex Machina? A framework for macro forecasting with machine learning," *SSRN Electronic Journal* [Preprint]. Available at: <https://doi.org/10.2139/ssrn.3579665>.
- Dauphin, J.-F. et al. (2022) "Nowcasting GDP - a scalable approach using DFM, machine learning and novel data, applied to European economies," *IMF Working Papers*, 2022(052), p. 1. Available at: <https://doi.org/10.5089/9798400204425.001>.
- Hopp, D. (2022) "Benchmarking econometric and machine learning methodologies in Nowcasting," *SSRN Electronic Journal* [Preprint]. Available at: <https://doi.org/10.2139/ssrn.4101997>.
- Fischer, T. and Krauss, C. (2018) "Deep learning with long short-term memory networks for financial market predictions," *European Journal of Operational Research*, 270(2), pp. 654–669. Available at: <https://doi.org/10.1016/j.ejor.2017.11.054>.
- Graves, A., Mohamed, A.-rahman and Hinton, G. (2013) "Speech recognition with deep recurrent neural networks," *2013 IEEE International Conference on Acoustics, Speech and Signal Processing* [Preprint]. Available at: <https://doi.org/10.1109/icassp.2013.6638947>.
- ha.G, S. et al. (2018) "Forecasting GDP using Arima and artificial neural networks models under Indian environment," *International Journal of Mathematics Trends and Technology*, 56(1), pp. 60–70. Available at: <https://doi.org/10.14445/22315373/ijmtt-v56p508>.
- Hastie, T., Friedman, J. and Tibshirani, R. (2017) *The elements of Statistical Learning: Data Mining, Inference, and prediction*. New York: Springer.
- Loermann J and Maas B (2019). Nowcasting US GDP with artificial neural networks. MPRA Paper No. 95459. University Library of Munich, Germany.
- Maccarrone, G., Morelli, G. and Spadaccini, S. (2021) "GDP forecasting: Machine learning, linear or autoregression?," *Frontiers in Artificial Intelligence*, 4. Available at: <https://doi.org/10.3389/frai.2021.757864>.
- Park, S. and Yang, J.-S. (2022) "Interpretable deep learning LSTM model for intelligent economic decision-making" *Knowledge-Based Systems*, 248, p. 108907. Available at: <https://doi.org/10.1016/j.knsys.2022.108907>.
- Soybilgen, B. and Yazgan, E. (2021) "Nowcasting US GDP using tree-based ensemble models and dynamic factors," *Computational Economics*, 57(1), pp. 387–417. Available at: <https://doi.org/10.1007/s10614-020-10083-5>.
- Tölö, E. (2020) "Predicting systemic financial crises with Recurrent Neural Networks," *Journal of Financial Stability*, 49, p. 100746. Available at: <https://doi.org/10.1016/j.jfs.2020.100746>.
- Woloszko, Nicolas. (2020) "Adaptive trees: A new approach to economic forecasting" *OECD Economics Department Working Papers* [Preprint]. Available at: <https://doi.org/10.1787/5569a0aa-en>.
- Yoon, J. (2020) "Forecasting of real GDP growth using machine learning models: Gradient boosting and Random Forest approach," *Computational Economics*, 57(1), pp. 247–265. Available at: <https://doi.org/10.1007/s10614-020-10054-w>.
- Zahara, S., Sugianto and Ilmuddaviq, M.B. (2020) "Consumer price index prediction using Long short term memory (Lstm) based cloud computing," *Journal of Physics: Conference Series*, 1456(1), p. 012022. Available at: <https://doi.org/10.1088/1742-6596/1456/1/012022>.
- Zhang, J., Wen, J. and Yang, Z. (2022) "China's GDP forecasting using long short term memory recurrent neural network and Hidden Markov model," *PLOS ONE*, 17(6). Available at: <https://doi.org/10.1371/journal.pone.0269529>.

Sumber: Berbagai sumber, IFGP Research.

Exhibit 11. Indikator Yang Digunakan

No	Indicator	Category
1	Purchasing Manager Index (Manufacturing)	Real
2	Cement Consumption	Real
3	Motor Sales	Real
4	Gross Domestic Product	Real
5	Gross Domestic Product (Consumption)	Real
6	Prompt Manufacturing Index	Real
7	Consumer Confidence Index	Real
8	Retail Sales Index	Real
9	Visitor Arrivals	Real
10	Consumer Price Index	Real
11	Wholesale Price Index (General)	Real
12	Wholesale Price Index (Export)	Real
13	Wholesale Price Index (Import)	Real
14	Industrial Product Index	Real
15	Hotel Occupancy	Real
16	Consumer Price Index (Core)	Real
17	Producer Price Index	Real
18	Capacity Utilization	Real
19	Prompt Manufacturing Index (Inventory)	Real
20	7 Day Reverse Repo Rate	Monetary
21	Money Supply (Broad)	Monetary
22	Credit Card	Monetary
23	Export	External
24	Import (Consumer Goods)	External
25	Import (Capital Goods)	External
26	Import (Raw Materials)	External

Sumber: Berbagai sumber, IFGP Research.

PT. Bahana Pembinaan Usaha Indonesia (Persero)

Gedung Graha CIMB Niaga, 18th Floor
Jl. Jendral Sudirman Kav. 58
RT.5/RW.3, Senayan, Kebayoran Baru
Kota Jakarta Selatan, DKI Jakarta 12190
☎ (+62) 021 2505080

 PT. Bahana Pembinaan Usaha Indonesia – Persero
 @indonesiafinancialgroup
 @ifg_id

Indonesia Financial Group (IFG)

Indonesia Financial Group (IFG) adalah BUMN Holding Perasuransian dan Penjaminan yang beranggotakan PT Asuransi Kerugian Jasa Raharja, PT Jaminan Kredit Indonesia (Jamkrindo), PT Asuransi Kredit Indonesia (Askrindo), PT Jasa Asuransi Indonesia (Jasindo), PT Bahana Sekuritas, PT Bahana TCW Investment Management, PT Bahana Artha Ventura, PT Bahana Kapital Investa, PT Graha Niaga Tata Utama, dan PT Asuransi Jiwa IFG. IFG merupakan holding yang dibentuk untuk berperan dalam pembangunan nasional melalui pengembangan industri keuangan lengkap dan inovatif melalui layanan investasi, perasuransian dan penjaminan. IFG berkomitmen menghadirkan perubahan di bidang keuangan khususnya asuransi, investasi, dan penjaminan yang akuntabel, prudent, dan transparan dengan tata kelola perusahaan yang baik dan penuh integritas. Semangat kolaboratif dengan tata kelola perusahaan yang transparan menjadi landasan IFG dalam bergerak untuk menjadi penyedia jasa asuransi, penjaminan, investasi yang terdepan, terpercaya, dan terintegrasi. IFG adalah masa depan industri keuangan di Indonesia. Saatnya maju bersama IFG sebagai motor penggerak ekosistem yang inklusif dan berkelanjutan.

Indonesia Financial Group (IFG) Progress

The Indonesia Financial Group (IFG) Progress adalah sebuah *Think Tank* terkemuka yang didirikan oleh Indonesia Financial Group sebagai sumber penghasil pemikiran-pemikiran progresif untuk pemangku kebijakan, akademisi, maupun pelaku industri dalam memajukan industri jasa keuangan.